PATENTS

IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

Applicant: Kenji Yamanishi, et al

Docket: 13931

Serial No.: unassigned

Dated: September 29, 2000

Filed: herewith

For:

DEGREE OF OUTLIER CALCULATION DEVICE, AND PROBABILITY

DENSITY ESTIMATION DEVICE AND FORGETFUL HISTOGRAM

CALCULATION DEVICE FOR USE THEREIN

Assistant Commissioner for Patents Washington, DC 20231

CLAIM OF PRIORITY

Sir:

Applicant in the above-identified application hereby claims the right of priority in connection with Title 35 U.S.C. §119 and in support thereof, herewith submits a certified copy of Japanese Patent Application 11 275437 (275437/1999) filed on September 29, 1999.

Respectfully submitted,

Paul J. Esatto, Jr.

Registration No. 30,749

Scully, Scott, Murphy & Presser 400 Garden City Plaza Garden City, NY 11530 (516) 742-4343 PJE/eg

CERTIFICATE OF MAILING BY "EXPRESS MAIL"

"Express Mail" Mailing Label Number: EL-680-252-143-US

Date of Deposit: September 29, 2000

I hereby certify that this correspondence is being deposited with the United States Postal Service "Express Mail Post Office to Addressee" service under 37 C.F.R. §1.10 on the date indicated above and is addressed to the Assistant Commissioner of Patents and Trademarks, Washington, D.C. 20231.

Dated: September 29, 2000

Michelle Mustafa

G:\NEC\1072\13931\AMEND

日本国特許庁 PATENT OFFICE IAPANESE GOVERNMENT

1c511 U.S. PTO 09/675637 09/29/00

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出 願 年 月 日 Date of Application:

1999年 9月29日

出 願 番 号 Application Number:

平成11年特許願第275437号

日本電気株式会社

CERTIFIED COPY OF PRIORITY DOCUMENT

2000年 6月 9日

特許庁長官 Commissioner, Patent Office 近藤隆厚



出証番号 出証特2000-3044438

【書類名】 特許願

【整理番号】 33509601

【提出日】 平成11年 9月29日

【あて先】 特許庁長官殿

【国際特許分類】 G06F 19/00

【発明者】

【住所又は居所】 東京都港区芝五丁目7番1号 日本電気株式会社内

【氏名】 山西 健司

【発明者】

【住所又は居所】 東京都港区芝五丁目7番1号 日本電気株式会社内

【氏名】 竹内 純一

【特許出願人】

【識別番号】 000004237

【氏名又は名称】 日本電気株式会社

【代理人】

【識別番号】 100088812

【弁理士】

【氏名又は名称】 ▲柳▼川 信

【手数料の表示】

【予納台帳番号】 030982

【納付金額】 21,000円

【提出物件の目録】

【物件名】 明細書 1

【物件名】 図面 1

【物件名】 要約書 1

【プルーフの要否】 要

【書類名】 明細書

【発明の名称】 外れ値度計算装置及びそれに用いる確率密度推定装置並びに忘却型ヒストグラム計算装置

【特許請求の範囲】

【請求項1】 実数ベクトル値のデータ列を入力として、各データの外れ値度合いを順次検出する外れ値度計算装置に使用され、前記データ列を順次読み込みつつ該データが発生する確率分布を正規分布の有限混合分布を用いて推定する確率密度推定装置であって、有限個の正規分布密度の各々の平均パラメータと分散パラメータの値および各正規分布の重みを記憶するパラメータ記憶手段と、入力データの値に対して、前記記憶手段からパラメータの値を読み込んで、各正規分布から該入力データが発生した確からしさを計算する確からしさ計算手段と、該確からしさ計算手段から確からしさを読み込み、各正規分布の平均と分散パラメータの値および各正規分布の重みパラメータを前記パラメータ記憶手段から読み込み、新たに読み込んだデータに応じて過去のデータを忘却しつつ更新して該記憶手段の内容を書き換えるパラメータ書換え手段とを含むことを特徴とする確率密度推定装置。

【請求項2】 請求項1記載の確率密度推定装置と、該確率密度推定装置により更新された有限混合分布のパラメータを使用して、この更新前後のパラメータの値および入力データから推定された確率分布に基づいて前記データの外れ値度合いを計算して出力する外れ値度計算手段とを含むことを特徴とする外れ値度計算装置。

【請求項3】 実数ベクトル値のデータ列を入力として、各データの外れ値度合いを順次検出する外れ値度計算装置に使用され、前記データ列を順次読み込みつつ該データが発生する確率分布を有限個の正規カーネル分布を用いて推定する確率密度推定装置であって、各カーネルの位置を表すパラメータの値を記憶するパラメータ記憶手段と、該記憶手段からパラメータの値を読み込んで、新たに読み込んだデータに応じて過去のデータを忘却しつつ更新して該パラメータ記憶手段の内容を書き換えるパラメータ書換え手段とを含むことを特徴とする確率密

度推定装置。

【請求項4】 請求項3の確率密度推定装置と、該確率密度推定装置により 更新された前記パラメータを使用して、更新前後のパラメータの値および入力データから推定された確率分布に基づいて前記データの外れ値度合いを計算して出力する外れ値度計算手段とを含むことを特徴とする外れ値度計算装置。

【請求項5】 離散値データを入力として、各データの外れ値度合いを順次 検出する外れ値度計算装置に使用され、順次入力される前記離散値データに対し てヒストグラムのパラメータを計算する忘却型ヒストグラム計算装置であって、 前記ヒストグラムのパラメータ値を記憶する記憶手段と、該記憶手段から前記パ ラメータ値を読み出して、入力データに基づいて過去のパラメータ値を忘却しつ つ更新して前記記憶手段の値を書き換えるパラメータ更新手段とを備え、前記記 憶手段のパラメータ値の幾つかを出力するようにしたことを特徴とする忘却型ヒ ストグラム計算装置。

【請求項6】 請求項5記載の忘却型ヒストグラム計算装置と、該忘却型ヒストグラム計算装置の出力と前記入力データから前記ヒストグラムに対する該入力データのスコアを計算するスコア計算手段とを含み、該スコア計算手段の出力を前記入力データの外れ値度として出力するようにしたことを特徴とする外れ値度計算装置。

【請求項7】 順次入力される離散値変量と連続値変量の両者で記述されたデータに対してその外れ値度を計算する外れ値度計算装置であって、離散値データ部分に対してヒストグラムを推定する請求項5記載の忘却型ヒストグラム計算装置と、前記ヒストグラムのセルの数と同じ数だけそれぞれ対応して設けられ、連続値データ部分に対して確率密度を推定する請求項1記載の確率密度推定装置と、前記離散値データ部分が前記ヒストグラムのどのセルに属するのかを判別して、対応する前記確率密度推定装置に連続データ部分を送り込むセル判別手段と、前記忘却型ヒストグラム計算装置と前記確率密度推定装置との出力値と前記入力データとから、推定された確率分布に基づいて前記入力データのスコアを計算するスコア計算手段とを含み、該スコア計算手段の出力を前記入力データの外れ値度として出力するようにしたことを特徴とする外れ値度計算装置。

【請求項8】 順次入力される離散値変量と連続値変量との両者で記述されたデータに対して、その外れ値度を計算する外れ値度掲載装置であって、前記離散値データ部分に対してヒストグラムを推定する請求項5の忘却型ヒストグラム計算装置と、前記ヒストグラムのセルの数と同じ数だけそれぞれ対応して設けられ、連続値データ部分に対して確率密度を推定する請求項3記載の確率密度推定装置と、前記離散値データ部分がヒストグラムのどのセルに属するのかを判別して、対応する前記確率密度推定装置に連続データ部分を送り込むセル判別手段と、前記忘却型ヒストグラム計算装置と前記確率密度推定装置との出力値と前記入力データとから、推定された確率分布に基づいて前記入力データのスコアを計算するスコア計算手段とを含み、該スコア計算手段の出力を前記入力データの外れ値度として出力するようにしたことを特徴とする外れ値度計算装置。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】

本発明は外れ値度計算装置及びそれに用いる確率密度推定装置並びに忘却型ヒストグラム計算装置に関し、特に多次元の時系列データから、これまでのデータのパターンに対して大きく外れる異常値や外れ値を検出する統計的外れ値検出、不正検出、詐欺検出技術に関するものである。

[0002]

【従来の技術】

かかる外れ値度計算装置は、多次元の時系列データから、これまでのデータパターンに対して大きく外れる異常値や外れ値を発見するために使用されるものであり、例えば、携帯電話の通話記録から、いわゆるなりすまし使用(クローニング:cloning)等の詐欺行為を発見したり、クレジッシカードの利用履歴から、異常な取引を発見したりする場合に利用される。

[0003]

従来の機械学習技術を用いた不正検出の方式としては、T. Fawcett とF. Provostによる方式(Combining data mining and machine learning for effective fraud detection, Proceedings of AI Approaches to Fraud Detection and Ris

k Management, pp:14-19,1997) や、J. Ryan, M. Lin, R. Miikkulainenによる方式(Intrusion detection with neural networks, Proceedings of AI Approaches to Fraud Detection and Risk Management, pp:72-77, 1997) 等が知られている。

[0004]

特に、統計的外れ値検出の考え方を利用したものに、P. BurgeとJ. Shaw-Tayl orによる方式(Detecting cellular fraud using adaptive prototypes, in Proceedings of AI Approaches to Fraud Detection and Risk Management, pp:9-13, 1997)がある。

[0005]

パラメトリックな有限混合モデルの学習アルゴリズムとしては、A. P. Dempster, N. M. Laird, D.B.RibinのEMアルゴリズム(Maximum likelihood from incomplete data via the EM algorithm, Journal of the Royal Statistical Society, B, 39(1), pp:1-38, 1977)が知られている。

[0006]

正規カーネル混合分布(同一の正規分布の有限個の混合)の学習アルゴリズムとしては、I. Grabec のプロトタイプ更新アルゴリズム(Self-organization of Neurons described by the maximum-entropy principle, Biological Cybernetics, vol. 63, pp. 403-409, 1990) が知られている。

[0007]

【発明が解決しようとする課題】

上述したT. FawcettとF. Provostによる方式や、J. Ryan, M.Lin, R. Miikkul ainen による方式は、不正であることが分かっているデータ(いわゆる教師付きデータ)から不正検出パターンを学習することによる不正検出の方式である。しかし、実際には不正データが十分揃えるのは難しく、よって精度良い学習が行えず、その結果として不正検出精度も低くなる。

[0008]

また、P. BurgeとJ. Shaw-Taylorによる方式は、同様な教師無しデータからの不正検出の方式である。しかし、それらはノンパラメトリックな短期モデルと長

期モデルの2つのモデルを用意して、それらの距離を外れ値の尺度として不正検 出を行うものであった。よって、短期モデルと長期モデルの統計的根拠が乏しく 、ゆえにそれらの距離の統計的意味が不明瞭であった。

[0009]

加えて、短期と長期の2つのモデル用意するために、計算上非効率であり、かつ連続値データのみでカテゴリカルデータを扱えない、ノンパラメトリックモデルのみを扱っているので、不安定かつ非効率であるといった問題もあった。

[0010]

また、統計モデルの学習アルゴリズムには、A. P. Dempster, N. M. Laird, D. B. RibinのEMアルゴリズムやI. Grabec のプロトタイプ更新アルゴリズムが知られているが、これらは過去の全てのデータを等しい重みをつけて学習しているので、パタンの変化があったときに対応できない。

[0011]

本発明の目的は、不正であるか否かがわかっていないデータ (教師無しデータ)を元に自動的に不正検出を行うことが可能な外れ値度計算装置及びそれに用いる確率密度推定装置並びに忘却型ヒストグラム計算装置を提供することである。

[0.012]

本発明の他の目的は、統計的意味が明瞭な外れ値判定尺度を採用し、短期/長期を1つにまとめたモデルを用いることによって、計算の効率化を実現し、カテゴリカルデータにも対応でき、ノンパラメトリックだけではなくパラメトリックなモデルも用いて安定で効率的な外れ値検出を行うことが可能な外れ値度計算装置及びそれに用いる確率密度推定装置並びに忘却型ヒストグラム計算装置を提供することである。

[0013]

本発明の更に他の目的は、過去のデータほど重みを減らし、忘却しながら学習するアルゴリズムを装置の中で実現することにより、パタンの変化にも柔軟に追従することが可能な外れ値度計算装置及びそれに用いる確率密度推定装置並びに忘却型ヒストグラム計算装置を提供することである。

[0014]

【課題を解決するための手段】

本発明によれば、実数ベクトル値のデータ列を入力として、各データの外れ値度合いを順次検出する外れ値度計算装置に使用され、前記データ列を順次読み込みつつ該データが発生する確率分布を正規分布の有限混合分布を用いて推定する確率密度推定装置であって、有限個の正規分布密度の各々の平均パラメータと分散パラメータの値および各正規分布の重みを記憶するパラメータ記憶手段と、入力データの値に対して、前記記憶手段からパラメータの値を読み込んで、各正規分布から該入力データが発生した確からしさを計算する確からしさ計算手段と、該確からしさ計算手段から確からしさを読み込み、各正規分布の平均と分散パラメータの値および各正規分布の重みパラメータを前記パラメータ記憶手段から読み込み、新たに読み込んだデータに応じて過去のデータを忘却しつつ更新して該記憶手段の内容を書き換えるパラメータ書換え手段とを含むことを特徴とする確率密度推定装置が得られる。

[0015]

また、本発明によれば、この確率密度推定装置と、該確率密度推定装置により 更新された有限混合分布のパラメータを使用して、この更新前後のパラメータの 値および入力データから推定された確率分布に基づいて前記データの外れ値度合 いを計算して出力する外れ値度計算手段とを含むことを特徴とする外れ値度計算 装置が得られる。

[0016]

更に本発明によれば、実数ベクトル値のデータ列を入力として、各データの外れ値度合い順次検出する外れ値度計算装置に使用され、前記データ列を順次読み込みつつ該データが発生する確率分布を有限個の正規カーネル分布を用いて推定する確率密度推定装置であって、各カーネルの位置を表すパラメータの値を記憶するパラメータ記憶手段と、該記憶手段からパラメータの値を読み込んで、新たに読み込んだデータに応じて過去のデータを忘却しつつ更新して該パラメータ記憶手段の内容を書き換えるパラメータ書換え手段とを含むことを特徴とする確率密度推定装置が得られる。

[0017]

更にはまた、本発明によれば、この確率密度推定装置(カーネル混合分布)と、該確率密度推定装置により更新された前記パラメータを使用して、更新前後のパラメータの値および入力データから推定された確率分布に基づいて前記データの外れ値度合いを計算して出力する外れ値度計算手段とを含むことを特徴とする外れ値度計算装置が得られる。

[0018]

また、本発明によれば、離散値データを入力として、各データの外れ値度合いを順次検出する外れ値度計算装置に使用され、順次入力される前記離散値データに対してヒストグラムのパラメータを計算する忘却型ヒストグラム計算装置であって、前記ヒストグラムのパラメータ値を記憶する記憶手段と、該記憶手段から前記パラメータ値を読み出して、入力データに基づいて過去のパラメータ値を忘却しつつ更新して前記記憶手段の値を書き換えるパラメータ更新手段とを備え、前記記憶手段のパラメータ値の幾つかを出力するようにしたことを特徴とする忘却型ヒストグラム計算装置が得られる。

[0019]

更に、本発明によれば、この忘却型ヒストグラム計算装置と、該忘却型ヒストグラム計算装置の出力と前記入力データから前記ヒストグラムに対する該入力データのスコアを計算するスコア計算手段とを含み、該スコア計算手段の出力を前記入力データの外れ値度として出力するようにしたことを特徴とする外れ値度計算装置が得られる。

[0020]

更にはまた、本発明によれば、順次入力される離散値変量と連続値変量の両者で記述されたデータに対してその外れ値度を計算する外れ値度計算装置であって、離散値データ部分に対してヒストグラムを推定する上記の忘却型ヒストグラム計算装置と、前記ヒストグラムのセルの数と同じ数だけそれぞれ対応して設けられ、連続値データ部分に対して確率密度を推定する上記の確率密度推定装置(正規混合分布)と、前記離散値データ部分が前記ヒストグラムのどのセルに属するのかを判別して、対応する前記確率密度推定装置に連続データ部分を送り込むセル判別手段と、前記忘却型ヒストグラム計算装置と前記確率密度推定装置との出

力値と前記入力データとから、推定された確率分布に基づいて前記入力データの スコアを計算するスコア計算手段とを含み、該スコア計算手段の出力を前記入力 データの外れ値度として出力するようにしたことを特徴とする外れ値度計算装置 が得られる。

[0021]

また、本発明によれば、順次入力される離散値変量と連続値変量との両者で記述されたデータに対して、その外れ値度を計算する外れ値度掲載装置であって、前記離散値データ部分に対してヒストグラムを推定する上記の忘却型ヒストグラム計算装置と、前記ヒストグラムのセルの数と同じ数だけそれぞれ対応して設けられ、連続値データ部分に対して確率密度を推定する上記の確率密度推定装置(カーネル混合分布)と、前記離散値データ部分がヒストグラムのどのセルに属するのかを判別して、対応する前記確率密度推定装置に連続データ部分を送り込むセル判別手段と、前記忘却型ヒストグラム計算装置と前記確率密度推定装置との出力値と前記入力データとから、推定された確率分布に基づいて前記入力データのスコアを計算するスコア計算手段とを含み、該スコア計算手段の出力を前記入力データの外れ値度として出力するようにしたことを特徴とする外れ値度計算装置がえられる。

[0022]

本発明の作用を述べる。本発明において、時系列データの一つの値をxとすると、入力データは多次元のデータであると想定して、xの内容は、例えば、一つの実数、多次元の実数値ベクトル離散値の属性、それらを並べた多次元のベクトル等である。携帯電話の場合には、

x = (通話開始時刻,通話持続時間,発話地域) が考えられるが、これは一例を示すにすぎないものである。

[0023]

×が従う確率分布の確率密度関数はデータ発生機構(例えば、ユーザの通話パターン)の性質を表す。本発明にかかる外れ値度計算装置は、時系列にデータが与えられる毎に確率密度関数を学習するものである。かかる状況下において、「外れ値度」は基本的に次の1,2で示す二つの考え方で計算する様にしている。

[0024]

1. 一つの入力データの外れ値度は、学習した確率密度が、その入力データを取込むことによって、学習する前と比較してどれだけ変化したかという量によって計算される。これは、いままで、学習されてきた確率密度関数と傾向が大きく異なるデータは、外れ値度が大きいと考えられるからである。より具体的には、データが入力される前後の確率密度の間の距離関数を外れ値度として計算するのである。

[0025]

2. これまでに学習で得られた確率密度関数の、入力データに対する尤度(確率密度関数の入力データに関する値)を計算する。この尤度が小さければ小さい程、外れ値度は大きいと考えられる。実際には、尤度の対数に負号を付けた値(負対数尤度)を外れ値度として出力する。

[0026]

また、上記の二つの関数の組み合わせ等も使用することができる。以上の様に、本発明による装置は、確率密度関数で、データ発生機構の統計的性質を表現し(確率密度推定装置の機能)、これに基づき、入力データがいかにデータ発生機構の性質から外れているかを、「外れ値度」として計算して出力する(外れ値度計算装置の機能)ものである。

[0027]

【発明の実施の形態】

次に、本発明の実施の形態について図面を参照して詳細に説明する。先ず、正 規混合分布を用いた確率密度推定装置について説明する。データx(d次元ベクトル値)が確率分布として、

【数1】

$$p(x|\theta) = \sum_{i=1}^{k} c_i p(x|\mu_i, \Sigma_i) \qquad ----(1)$$

に従って発生するとする。

[0028]

但し、

【数2】

$$p(x|\mu_{i}, \Sigma_{i}) = \frac{1}{(2\pi)^{d/2}|\Sigma_{i}|^{1/2}} exp\left(-\frac{1}{2}(x - \mu_{i})^{T} \Sigma_{i}^{-1}(x - \mu_{i})\right)$$

$$(i = 1, \dots, k)$$

であるものとし、また、μi は n 次元のベクトルであり、 n 次元正規分布の平均値を表すパラメータであり、Σi は n 元正方行列であり、 n 元正規分布の分散を表すパラメータである。また、 c i は正規分布の重みを表わすパラメータである。ここで、 k は重ね合わせの数を表す整数であり、

【数3】

$$c_i \geq 0$$

$$\sum_{i=1}^k c_i = 1$$

が成り立つ。また、 $\theta=$ (ci, μ i, Σ i, ……, ck, μ k, Σ k) をパラメータベクトルとする。

[0029]

図1は本発明の一実施例による確率密度推定装置のブロック図である。ここでは、忘却の速さを表す定数 r ($0 \le r \le 1$ であり、r が小さい程、過去のデータを速く忘却する)と、正規分布の重ね合わせの数 k とが、予め与えられているものとする。また、 α ($\alpha > 0$) なるパラメータも用いるが、この値も予め与えられているものとする。

[0030]

図1において、パラメータ記憶装置13は上述のパラメータ θ を記憶する装置であり、パラメータ書換え装置12は、d次元ベクトル μ i '及びd元正方行列 Σ i 'をも記憶することができる。尚、10はデータ入力部を示し、11は確からしさを計算する確からしさを計算装置であり、14はパラメータ出力部を示し

ている。

[0031]

図2は図1のブロックの概略動作を示すフロー図であり、図1の装置は以下の様に動作する。先ず、データが読込まれる前にパラメータ記憶装置13に格納されている各パラメータの値が初期化される(ステップS10)。次に、 t番目のデータxt が入力される度に、以下の様に動作する。入力xt が確からしさ計算装置11およびパラメータ書換え装置12に渡されて(ステップS11)格納される。

確からしさ計算装置 1 1 はパラメータ記憶装置 1 3 より現在のパラメータの値 θ を読込み、これを用いて各正規分布がデータx t を発生した各確からしさ γ i $(i=1,\ 2,\ \cdots\cdots,\ K)$ を、

【数4】

$$\gamma_i := (1 - \alpha r) \frac{c_i p(x_t | \mu_i, \Sigma_i)}{\sum_{i=1}^k c_i p(x_t | \mu_i, \Sigma_i)} + \frac{\alpha r}{k}$$

なる式によって計算し(ステップS12)、パラメータ書換え装置12に送り込む。パラメータ書換え装置12はパラメータ記憶装置13から現在のパラメータの値を読取りつつ、送り込まれた確からしさ γ i を用いて、パラメータの値の更新結果を、下記の式(2)~(6)に示す様に、各i=1, 2, ……, kについて順次計算しつつパラメータ記憶装置13に記憶されているパラメータの値を書換えて行く(ステップS13)。尚、これ等式(2)~(6)における":="なる記号は右辺の項を左辺へ代入することを意味する。

[0033]

【数5】

$$c_{i} := (1 - r)c_{i} + r\gamma_{i} ----- (2)$$

$$\mu_{i}' := (1 - r)\mu_{i}' + r\gamma_{i} \cdot x_{t} ----- (3)$$

$$\mu_{i} := \frac{\mu_{i}'}{c_{i}} ----- (4)$$

$$\Sigma_{i}' := (1 - r)\Sigma_{i}' + r\gamma_{i} \cdot x_{t}x_{t}^{T} ----- (5)$$

$$\Sigma_{i} := \frac{\Sigma_{i}'}{c_{i}} - \mu_{i}\mu_{i}^{T} ----- (6)$$

$$[0 0 3 4]$$

そして、パラメータ記憶装置13は書換えられたパラメータの値を出力する(ステップS14)。この更新規則は(t-1)番目のデータについて、(1-r) だけの重みをつけた対数尤度を極大化することに相当しており、過去のデータを次第に忘却していくような推定を実現している。従って、1/r個ほど前までのデータを用いて学習していることになる(1は正の整数である)。

【0035】
これは
$$(1-r)^{-1}=1/2$$
の解が、
 $1=-(\log 2)/\log (1-r) \sim (\log 2)/r$ であることによる。

[0036]

この様に、確率密度分布が上記の式(1)で表された関数を採用しており、この関数は有限個のパラメータで完全に指定されるものである。よって、この確率密度関数を表現するには、パラメータの値を指定すれば十分であることから、図1に示したパラメータ出力部14により、当該確率密度関数が推定可能となる。この推定された確率密度関数を使用して、入力データの外れ値度を計算する装置について、図3にブロック図を示す。

[0037]

図3は外れ値度掲載装置の一実施例を示すブロック図である。本装置は、入力部20と、図1に示した確率密度推定装置21と、入力データと確率密度推定装置21からのパラメータとから推定された確率分布に基きデータの外れ値度、すなわちスコアを計算するスコア計算装置22と、その結果を出力する出力部23

とからなっている。この図3に示す装置は図4に示したフローに従い、t番目の データxt が入力される度に、以下の順序で動作する。

入力xt は確率密度推定装置21 (正規混合分布) およびスコア計算装置22 に渡されて (ステップS20) 格納される。確率密度推定装置21は入力されたデータに応じて格納しているパラメータの値を更新し (ステップS21)、新しい値をスコア計算装置22に入力する。スコア計算装置22では、入力されたデータ、パラメータの値、過去に渡されたパラメータの値を用いてスコア (ステップS22) を計算して出力する (ステップS23)。外れ値度を示すスコアは例えば、平方距離、Hellinger 距離、更には対数損失を用いて計算される。

以下、具体的に説明する。データ $\mathbf{x}^{\mathbf{t}} = \mathbf{x} \ \mathbf{x} \ \mathbf{x} \ \mathbf{x} = \mathbf{x} \ \mathbf{x} \ \mathbf{x} \ \mathbf{x} \ \mathbf{x} \ \mathbf{x} \ \mathbf{t}$ によって推定された パラメータを $\mathbf{\theta}^{\mathbf{t}}$ として、

$$p^{(t)} \quad (x) = p \quad (x \mid \theta^{(t)})$$

と表し、確率分布 p と q に対して、 d s (p , q)で二つの分布の間の平方距離を、 d h (p , q)でHellinger 距離を表すとき、スコアとして、

【数 6】

$$\begin{split} d_s(p^{(t)},p^{(t-1)}) &= \int \left(p^{(t)}(x)-p^{(t-1)}(x)\right)^2 dx \\ d_h(p^{(t)},p^{(t-1)}) &= \int \left(\sqrt{p^{(t)}(x)}-\sqrt{p^{(t-1)}(x)}\right)^2 dx \end{split}$$

のいずれかを用いることができる。対数損失を用いる場合は、

$$-1 \circ g p^{(t-1)} (xt)$$
.

で計ることができる。これらはただちに、Tを正の整数として $ds (p^{(t)})$ $p^{(t-T)}$)等に一般化できる。

[0040]

次に、本発明による確率密度推定装置の他の実施の形態を示す。この例では、 データ発生のモデルとして、カーネル混合分布である 【数7】

$$p(x|q) = \frac{1}{k} \sum_{i=1}^{k} w(x:q_i)$$

を使用する。ここで、 " ω (・:・) はカーネル関数とよばれるもので、正規密 度関数

【数8】

$$w(x: w_t) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(x - q_i)^T \Sigma^{-1}(x - q_i)\right)$$

の形で与えられる(これを正規分布カーネルと呼ぶ)。Σは対角行列であり、

$$\Sigma = \text{diag} (\sigma^2, \dots, \sigma^2)$$

である。尚、 σ は与えられた正数である。各 q i は d 次元のベクトルであり、各カーネル関数の位置を指定するパラメータである。 $\{q$ i $\}$ はプロトタイプと呼ばれる。尚、x m σ α m α m

[0041]

図5はカーネル混合分布を使用した確率密度推定装置のブロック図である。パラメータ記憶装置32はq=(q1,q2,……qk)を記憶する機能を有する。尚、図5において、30は入力部、31はパラメータ書換え装置、33は出力部である。図5に示した装置は図6のフローに従って以下の様に動作する。先ず、データが読込まれる前にパラメータ記憶装置32に格納されているパラメータの値を初期化する(ステップS30)。そして、t番目のデータxtが入力される度に、以下の順序で動作する。入力xtがパラメータ書換え装置31に渡され(ステップS31)て格納される。パラメータ書換え装置31はパラメータ記憶装置32より、現在のパラメータの値 qを読込み、次式の連立一次方程式(k=

$$\sum_{j=1}^{K} \sum_{m=1}^{d} C_{jmkl} \triangle q_{jm} = rB_{kl} \qquad ----(7)$$

但し,

$$Bk\ell = K \cdot (x_{t+1}, \ell - q_{k\ell}) \exp(-\frac{|x_{t+1} - q_{k}|^{2}}{4\sigma^{2}}) - \sum_{i=1}^{K} (q_{i\ell} - q_{k\ell}) \exp(-\frac{|q_{i} - q_{k}|^{2}}{4\sigma^{2}})$$

$$C_{jmk\ell} = (\delta_{m\ell} - \frac{(q_{k\ell} - q_{j\ell})(q_{km} - q_{jm})}{2\sigma^{2}}) \exp(-\frac{|q_{k} - q_{j}|^{2}}{4\sigma^{2}})$$

(δ mlはクロネッカーのデルタを表す。すなわち、m=1 のときに1 を、そうでないとき 0 に等しい)の解 Δ q を求め、 $q:=q+\Delta$ q としてパラメータ記憶装置 3 2 に格納されているパラメータの値を書換える(ステップS 3 2)。パラメータ記憶装置 3 2 は書換えられたパラメータの値を出力する(ステップS 3 3)

[0042]

以上の更新規則において、 r は忘却の速さを制御するパラメータとなっている。 すなわち、該規則を順次適用して得られるカーネル混合分布は

【数10】

$$\sum_{\tau=2}^{t} r(1-r)^{t-\tau} w(x:x\tau) + (1-r)^{t-1} w(x:x_1) \qquad ---- (8)$$

なる確率密度からの平方距離を最小化する。P. Burge とJ. Shaw-Taylorが採用しているI. Grabec によるアルゴリズムは、上記においてrの部分を定数ではなく、 $1/\tau$ にしたものに対応している。その場合は式(8)に対応する式は、

【数11】

$$\sum_{\tau=1}^{t} (1/t) w(x : x_{\tau})$$

という単純なものになる。

[0043]

この図5に示したカーネル混合分布を使用した確率密度推定装置から得られた パラメータを用いて、入力データの外れ値度を算出する外れ値度算出装置の例が 図7に示されている。図7において、40は入力部、41は図5の確率密度推定 装置、42はスコア計算装置、43は出力部である。

[0044]

図7に示した装置は t 番目のデータ x t が入力される度に、図8に示すフローに従い以下の順序で動作する。入力 x t が確率密度推定装置 4 1 (カーネル混合分布) およびスコア計算装置 4 2 に渡されて(ステップ S 4 0) 格納される。確率密度推定装置 4 1 は入力されたデータに応じて格納しているパラメータの値を更新し(ステップ S 4 1)、新しい値をスコア計算装置 4 2 に供給する。スコア計算装置 4 2 では、入力されたデータ、パラメータの値、過去に渡されたパラメータの値を用いてスコアを計算して出力する(ステップ S 4 2 , S 4 3)。この場合に用いられるスコア関数には、図3に示した外れ値度計算装置と同様のものを用いることができる。

[0045]

図9は本発明による忘却型ヒストグラム計算装置の全体構成図である。パラメータ更新装置51に離散値データが順次入力され、パラメータ更新装置51には、ヒストグラム記憶装置52が接続され、ヒストグラム記憶装置52はヒストグラムのパラメータ値を記憶し、これらを出力する。尚、50は入力部、53は出力部である。

[0046]

図10は図9の装置の動作を示すフローである。離散値データはn個の変数で 指定されているとする。いま、n次元のデータ空間が予めN個の排反なセルに分 割されているとし、これらのセル上にヒストグラムが構成されるものとする。ヒ ストグラムは確率分布を表し、(p1,……,pN)

【数12】

(但し、
$$p_j$$
は、 $\sum_{j=1}^{N} p_j = 1$, $p_j \ge 0$ を満たすものとする)

をパラメータとする。

[0047]

ここに、p j は j 番目のセルの生起確率である。T 0 (j) = 0 (j = 1, … …, N), 0 < r < 1, $\beta > 0$ は与えられた数とし、パラメータの初期を、

$$p^{(0)}$$
 (1) = ... = $p^{(0)}$ (N) = 1/N

とする (ステップ S 5 0)。

[0048]

パラメータ更新装置 5 1 は t 番目に入力されたデータに対して (ステップ S 5 1)、

【数13】

$$T_{t}(j) = (1-r)T_{t-1}(j) + \delta_{t}(j)$$

$$P^{(t)}(j) = \frac{T_{t}(j) + \beta}{(1-(1-r)^{m})/r + N\beta}$$

なる更新を行う(ステップS52)。ここに、 δ t (j)は、t番目のデータが j番目のセルに入れば 1 、そうでなければ 0をとる。この更新を全てのセルについて行う。

をヒストグラムの新しいパラメータとして更新する。これらの値はヒストグラム

記憶装置52に送られる。ヒストグラム記憶装置52は過去の幾つかのパラメータ値を記憶しており、それらの一部を出力する(ステップS53)。

[0050]

パラメータ更新装置 5 1 は、各ステップで t 時刻前のデータに、(1 - r) t だけの重みを掛けて算出している。この重み付けは、過去のデータほど徐々に忘れていくことを示しており、忘却しながら学習するアルゴリズムが装置の中で実現されている。これにより、ユーザパターンの変化に柔軟に追随することが可能となる。

[0051]

なお、忘却型ヒストグラムとは、カテゴリ変数上の確率分布を表し、連続変数上の確率密度関数と同様に、データの発生機構の統計的性質を表現するものである。よって、この「忘却型ヒストグラム計算装置」と「外れ値度計算装置」との関係と全く関係は、上述した「確率密度推定装置」と「外れ値度計算装置」との関係と全く同一である。すなわち、「忘却型ヒストグラム計算装置」でデータの発生機構の統計的計算を表現し、これに基づいて「外れ値度計算装置」が入力データがいかにデータ発生機構の性質から外れているかを「外れ値度」として計算することになる。

[0052]

そこで、図11に図9に示した忘却型ヒストグラム計算装置を使用した外れ値度計算装置の全体構成を示しており、図12はその動作フローである。入力部60からの離散値データは忘却型ヒストグラム計算装置61とスコア計算装置62とに順次入力される(ステップS61)。忘却型ヒストグラム計算装置61には、スコア計算装置62が接続され、忘却型ヒストグラム計算装置61は入力データからヒストグラムのパラメータ値を出力し(ステップS62)、スコア計算装置62に送る。スコア計算装置62は入力データと忘却型ヒストグラム計算装置61の出力を入力として、入力データの外れ値度合のスコアを計算する(ステップS63)。

[00.53]

この場合におけるスコアの計算法としては、連続値データの場合と同様、平方

距離、Hellinger 距離、対数損失等を用いる。但し、ヒストグラムでは、 j番目のセルに入るデータxについての時刻tにおける確率値をp (t) (x) = p (t)

(j) / Lj で計算する。ここに、Lj はj番目のセルに入る点の数であり、 $p^{(t)}$ (j) は時刻 t におけるj番目のセルの確率値である。これを利用して、平方距離 ds ($p^{(t)}$, $p^{(t-1)}$) と、 $ext{Hellinger}$ 距離 dh ($ext{p}^{(t)}$, $ext{p}^{(t-1)}$) とは、それぞれ、

【数14】

$$\begin{split} d_s(p^{(t)},p^{(t-1)}) & \stackrel{\text{def}}{=} & \sum_x \left(p^{(t)}(x) - p^{(t-1)}(x) \right)^2, \\ d_h(p^{(t)},p^{(t-1)}) & \stackrel{\text{def}}{=} & \sum_x \left(\sqrt{p^{(t)}(x)} - \sqrt{p^{(t-1)}(x)} \right)^2. \end{split}$$

で計算する。

[0054]

スコア計算装置 62 がこれらを計算するには、忘却型ヒストグラム計算装置 61 から、 $p^{(t)}$ と $p^{(t-1)}$ とのパラメータ値をもらうように設定する。また、対数損失は時刻 10 の入力データ 10 に対して、

$$-\log p^{(t-1)}$$
 (xt)

で計算する。

[0055]

以上のスコアは推定された分布の変化を統計的距離で計ったもの、あるいは入 カデータの推定された分布に対する対数損失という意味を有し、いずれも統計的 意味が明瞭である。

[0056]

図13は図1に示した正規混合分布の確率密度推定装置と図9に示した忘却型 ヒストグラム計算装置とを用いた本発明の他の外れ値度計算装置の実施例の全体 構成図であり、図14はその動作フローである。離散値変量と連続値変量の両者 で記述された入力データは忘却型ヒストグラム計算装置71とセル判別装置73 とスコア計算装置74に順次入力される(ステップS71)。セル判別装置73 にはN個の正規混合分布用の確率密度計算装置721~72Nが接続されている 。ここに、Nは忘却型ヒストグラム計算装置71のヒストグラムでセルの数である。全ての確率密度計算装置721~72Nと忘却型ヒストグラム計算装置71 にスコア計算装置74が接続されている。

[0057]

忘却型ヒストグラム計算装置 7 1 は入力データの離散データ部分だけからヒストグラムのパラメータを計算し(ステップ S 7 2)、これをスコア計算装置 7 4 に送る。セル判別装置 7 3 は入力データの離散データ部分がヒストグラムのどのセルに属するのかを判別して(ステップ S 7 3)、対応する確率密度推定装置に連続データ部分を送り込む。

[0058]

確率密度計算装置 7 2 1 ~ 7 2 N は入力データが送り込まれたときにだけ、確率密度のパラメータを計算し(ステップ S 7 4)、これをスコア計算装置 7 4 に送り込む。スコア計算装置 7 4 は入力データと忘却型ヒストグラム計算装置 7 1 の出力と確率密度計算装置 7 2 1 ~ 7 2 N のいずれかからの出力を入力として、もとの入力データのスコアを計算し(ステップ S 7 5)、これを出力とする(ステップ S 7 6)。

[0059]

スコア計算装置 7 4 はスコアを、例えば、確率分布の変化度合をHellinger 距離で測るか、または入力データに対する確率分布の負対数尤度(対数損失)で計算する。カテゴリカル変数をまとめたベクトルをx、連続値変数をまとめたベクトルをyとする。xとyの同時分布を以下のように表す。

$$p(x, y) = p(x) p(y | x)$$

[0060]

【数15】

$$d_{h}(p^{(t)}, p^{(t-1)}) = 2 - 2 \sum_{x} \sqrt{p^{(t)}(x)p^{(t-1)}(x)} \int \sqrt{p^{(t)}(y|x)p^{(t-1)}(y|x)} dy$$

これらは直ちに、Tを正の整数として $\mathbf{p}^{(\mathbf{t})}$ と $\mathbf{p}^{(\mathbf{t}-\mathbf{T})}$ の距離に一般化される。 【0061】

また、対数損失は以下で計算する。

【数16】

$$-\log p^{(t-1)}(x_t) - \log p^{(t-1)}(y_t|x_t)$$

[0062]

図15は図5のカーネル混合分布による確率密度推定装置と図9に示した忘却型ヒストグラム計算装置とを使用した本発明の外れ値度計算装置の全体構成図であり、図16はその動作フローである。離散値変量と連続値変量の両者で記述された入力データは忘却型ヒストグラム計算装置81とセル判別装置83とスコア計算装置84に順次入力される(ステップS81)。セル判別装置83にはN個のカーネル混合分布用の確率密度計算装置821~82Nが接続されている。ここに、Nは忘却型ヒストグラム計算装置81のヒストグラムでセルの数である。

[0063]

全ての確率密度計算装置 8 2 1 ~ 8 2 Nと忘却型ヒストグラム計算装置 8 1 にスコア計算装置 8 4 が接続されている。忘却型ヒストグラム計算装置 8 1 は入力データの離散データ部分だけからヒストグラムのパラメータを計算し(ステップ S 8 2)、これをスコア計算装置 8 4 に送る。セル判別装置 8 3 は入力データの離散データ部分がヒストグラムのどのセルに属するのかを判別して(ステップ S 8 3)、対応する確率密度推定装置に連続データ部分を送り込む。確率密度計算装置 8 2 1 ~ 8 2 N は入力データが送り込まれたときにだけ、確率密度のパラメ

ータを計算し(ステップS84)、これをスコア計算装置84に送り込む(ステップS85)。

[0064]

スコア計算装置84は入力データと忘却型ヒストグラム計算装置81の出力と確率密度計算装置821~82Nのいずれかからの出力を入力として、もとの入力データのスコアを計算し、これを出力とする(ステップS86)。スコアの計算方法は図13に示した外れ値度計算装置と同様である。

【図面の簡単な説明】

【図1】

本発明による確率密度推定装置(正規混合分布)の一例の構成を示す図である

【図2】

図1の装置の動作フロー図である。

【図3】

図1の装置を使用した外れ値度計算装置の例を示す構成図である。

【図4】

図3の装置の動作フロー図である。

【図5】

本発明による確率密度推定装置(混合カーネル分布)の一例の構成を示す図である。

【図6】

図5の装置の動作フロー図である。

【図7】

図6の装置を使用した外れ値度計算装置の例を示す構成図である。

【図8】

図7の装置の動作フロー図である。

【図9】

本発明による忘却型ヒストグラム計算装置の一例の構成を示す図である。

【図10】

図9の装置の動作フロー図である。

【図11】

図10の装置を使用した外れ値度計算装置の例を示す構成図である。

【図12】

図11の装置の動作フロー図である。

【図13】

図1および図9の装置を使用した外れ値度計算装置の例を示す構成図である。

【図14】

図13の装置の動作フロー図である。

【図15】

図5および図9の装置を使用した外れ値度計算装置の例を示す構成図である。

【図16】

図15の装置の動作フロー図である。

【符号の説明】

11 確からしさ計算装置

12,31 パラメータ書換え装置

13,32 パラメータ記憶装置

21, 721~72N 確率密度推定装置(正規混合分布)

22, 42, 62, 74, 84 スコア計算装置

41,821~82N 確率密度推定装置(混合カーネル分布)

51 パラメータ更新装置


52 ヒストグラム記憶装置

61,71,81 忘却型ヒストグラム計算装置

73,83 セル判別装置


【書類名】 図面

【図1】




確率密度推定装置(正規混合分布)

【図2】




【図3】




外れ値度計算装置

【図4】




【図5】




確率密度推定装置(カーネル混合分布)

【図6】




【図7】




外れ値度計算装置

【図8】




【図9】




忘却型ヒストグラム計算装置

【図10】




【図11】




外れ值度計算装置


【図12】




【図13】




【図14】



【図15】



【図16】



【書類名】 要約書

【要約】

【課題】 大規模なデータの集合の中から、統計的外れ値、不正なデータ、詐欺 に関わるデータ等の異常なデータを、教師無しのデータから発見する。

【解決手段】 一つの入力データの外れ値度は、学習した確率密度が、その入力データを取込むことによって、学習する前と比較してどれだけ変化したかという量によって計算される。これは、いままで、学習されてきた確率密度関数と傾向が大きく異なるデータは、外れ値度が大きいと考えられるからである。より具体的には、データが入力される前後の確率密度の間の距離関数を外れ値度として計算する。そこで、確率密度推定装置21により、大量データを逐次的に読込みつつ適応的に不正データの発生する確率分布を推定し、この推定確率分布に基づき各データの外れ値度を、スコア計算装置22で計算して出力する。

【選択図】 図3

出願人履歴情報

識別番号

[0000004237]

1. 変更年月日

1990年 8月29日

[変更理由]

新規登録

住 所

東京都港区芝五丁目7番1号

氏 名

日本電気株式会社